



Евгений Моргунов

Сибирский государственный аэрокосмический университет науки и технологий
имени академика М. Ф. Решетнева
г. Красноярск

PGDAY'17
RUSSIA

КОНФЕРЕНЦИЯ
ПО БАЗАМ ДАННЫХ


Использование метода Data Envelopment Analysis (DEA) для оценки эффективности работы специалистов по базам данных



«Лучшим каждому кажется то, к чему он имеет охоту» (К. Прутков)

Цель доклада — проинформировать уважаемых коллег о методе Data Envelopment Analysis (DEA) и способствовать его продвижению в ваших организациях

1. Понятие эффективности
2. Краткое описание метода DEA
3. Примеры использование метода DEA
4. Программное обеспечение
5. Метод DEA в России
6. Полезные веб-ресурсы



Проблема

Техническая сторона дела:

- базы данных
- разделяемые буфера (shared buffers)
- ядро операционной системы
- и т. д.

А специалисты? Их квалификация и эффективность работы?

Гипотетическая ситуация в компании N


- Проектирование и администрирование баз данных, много различных проектов
- Эти базы данных отличаются друг от друга по количеству таблиц, внешних ключей, столбцов в таблицах, общему объему базы данных (Гб, Тб, число строк) и по другим показателям.
- Работники отличаются по уровню квалификации: высокий и средний
- В течение месяца на каждый проект затрачивается некоторое количество человеко-часов времени специалистов каждого уровня квалификации. Затраты труда – это использованные ресурсы
- Продукцией являются базы данных различной сложности, спроектированные или обслуженные этими специалистами
- Вопрос: насколько эффективно работали наши специалисты в каждом из проектов?

Взгляд на понятие эффективности с двух позиций

- Эффективность — степень достижения цели с учетом затрат ресурсов и времени
 - По-английски — «effectiveness»

Результаты

- Эффективность = $\frac{\text{Результаты}}{\text{Затраты}}$
 - По-английски — «efficiency»



Эффективность системы

- эффективность — комплексное свойство любой целенаправленной деятельности
- проявляется только в процессе функционирования системы
- отражает степень пригодности системы для ее использования по назначению
- Эффективность системы определяется
 - Используемой технологией функционирования
 - Качеством управления
 - Условиями функционирования
 - Качеством ресурсов
 - Структурой системы

История возникновения метода


Метод Data Envelopment Analysis (DEA) предложили в 1978 г. американские ученые A. Charnes, W. W. Cooper, E. Rhodes

Charnes, A. Measuring the efficiency of Decision Making Units [Text] / A. Charnes, W. W. Cooper, E. Rhodes // European journal of operational research. – 1978. – Vol. 2. – P. 429–444.


Они основывались на идеях, изложенных в статье M. J. Farrell, опубликованной в 1957 г.

Farrell, M. J. The measurement of productive efficiency [Text] / M. J. Farrell // Journal of The Royal Statistical Society, Series A (General), Part III. – 1957. – Vol. 120. – P. 253–281.

Идея метода DEA



Постоянный эффект масштаба




Переменный эффект масштаба

Стрелками показано направление проецирования объектов на границу эффективности (ориентация на вход или на выход)

Метод Data Envelopment Analysis

- Метод является способом оценки производственной функции
- Граница эффективности является базовым понятием метода
- Она строится в многомерном пространстве входных и выходных показателей, описывающих оцениваемые объекты
- Входные показатели – ресурсы,
выходные показатели – продукция
- Степень эффективности конкретного объекта определяется расстоянием между точкой, соответствующей ему, и границей эффективности

Два входа и один выход (ориентация на вход)



- Эффективность объекта P :
$$\text{Eff} = \partial Q / \partial P$$
- A, B, C и D – эффективные объекты
- SS' – граница эффективности

Модель метода DEA (ориентация на вход)

$$\min_{\theta, \lambda} (\theta),$$

$$-\mathbf{y}_j + \mathbf{Y}\lambda \geq \mathbf{0},$$

$$\theta \mathbf{x}_j - \mathbf{X}\lambda \geq \mathbf{0},$$

$$\lambda \geq \mathbf{0}.$$

дополнительное ограничение

$$\sum_{j=1}^n \lambda_j = 1$$

- n – число объектов
- m – число входных показателей
- s – число выходных показателей
- X – матрица входных показателей для всех n объектов (размерность $m \times n$)
- Y – матрица выходных показателей для всех n объектов (размерность $s \times n$)
- x_j и y_j – вектор-столбцы входных и выходных показателей для j -го – оцениваемого – объекта
- λ – вектор констант (размерность $n \times 1$)

скаляр $\theta \leq 1$ – мера (показатель) эффективности j -го объекта

Модель метода DEA (ориентация на выход)

$$\max_{\varphi, \lambda} (\varphi),$$

$$-\varphi \mathbf{y}_j + \mathbf{Y}\lambda \geq \mathbf{0},$$

$$\mathbf{x}_j - \mathbf{X}\lambda \geq \mathbf{0},$$

$$\lambda \geq \mathbf{0}.$$

дополнительное ограничение

$$\sum_{j=1}^n \lambda_j = 1$$

- n – число объектов
- m – число входных показателей
- s – число выходных показателей
- X – матрица входных показателей для всех n объектов (размерность $m \times n$)
- Y – матрица выходных показателей для всех n объектов (размерность $s \times n$)
- x_j и y_j – вектор-столбцы входных и выходных показателей для j -го – оцениваемого – объекта
- λ – вектор констант (размерность $n \times 1$)

скаляр $\varphi \geq 1$ – мера (показатель) эффективности j -го объекта

Правила применения метода DEA (1)

- Задача решается N раз (т. е. для каждого объекта):
 - если $\theta = 1 (\varphi = 1)$, то объект эффективен;
 - если $\theta < 1 (\varphi > 1)$, то объект неэффективен
- Неэффективные объекты можно спроектировать на границу эффективности, получив линейную комбинацию $(\mathbf{X}\lambda, \mathbf{Y}\lambda)$ – гипотетический эталонный объект

Правила применения метода DEA (2)

- Для объектов с $\theta < 1$ могут быть установлены цели:
пропорциональное сокращение их входных показателей в θ раз
при сохранении выходных показателей на прежнем уровне
- Для объектов с $\varphi > 1$ могут быть установлены цели:
пропорциональное увеличение их выходных показателей в φ
раз при сохранении входных показателей на прежнем уровне

Привлекательные свойства метода DEA (1)

- позволяет вычислить один агрегированный – скалярный – показатель для каждого объекта
- может одновременно обрабатывать много входов и много выходов, каждый из которых при этом может измеряться в различных единицах измерения
- позволяет учитывать внешние по отношению к рассматриваемой системе переменные – факторы окружающей среды
- не требует априорного указания весовых коэффициентов для переменных, соответствующих входным и выходным показателям при решении задачи оптимизации

Привлекательные свойства метода DEA (2)

- не налагает никаких ограничений на функциональную форму зависимости между входами и выходами
- позволяет при необходимости учесть предпочтения менеджеров, касающиеся важности тех или иных входных или выходных переменных
- производит конкретные оценки желательных изменений во входах/выходах, которые позволили бы вывести неэффективные объекты на границу эффективности
- формирует Парето-оптимальное множество точек, соответствующих эффективным объектам
- концентрируется на выявлении примеров так называемой *лучшей практики* (best practice), а не на каких-либо усредненных тенденциях, как, например, регрессионный анализ

Сфера применения метода

- государственное управление
- промышленность и сельское хозяйство
- военная сфера
- образование и здравоохранение
- транспорт
- финансовая сфера и торговля
- энергетика и энергоснабжение
- спорт
- А сфера информационных технологий?

Пример – администрирование БД


Объекты исследования – проекты по администрированию существующих баз данных. Каждый проект описывается следующими показателями:

- число человеко-часов труда специалиста высокой квалификации
- число человеко-часов труда специалиста средней квалификации
- число таблиц в базе данных
- число внешних ключей (оно отражает сложность связей в БД)
- объем базы данных (в гигабайтах)

Определение набора показателей тоже может являться отдельной задачей

Исходные данные

Номер проекта	Число человеко-часов высокой квалификации	Число человеко-часов средней квалификации	Число таблиц	Число внешних ключей	Объем базы данных (Гб)
1	5	6	5	3	2
2	5	12	6	3	6
3	6	3	12	8	1
4	9	3	7	4	4
5	2	3	4	2	1
6	5	3	5	4	3
7	6	9	7	4	5
8	2	1	6	4	1
9	5	8	5	3	1
10	8	6	10	4	2
11	3	2	6	2	5
12	5	4	6	3	4
13	4	8	15	11	2
14	7	4	6	2	4
15	4	5	4	2	3



Выбор модели

- Эффект масштаба – переменный, т. к. исходим из предположения о том, что зависимость между числом специалистов и объемом и качеством работы будет нелинейной
- Ориентация модели – на вход, т. к. повышение эффективности работы возможно за счет сокращения времени, затрачиваемого на администрирование
- В качестве *входных* показателей выбраны два показателя временных затрат
- В качестве *выходных* показателей выбраны число таблиц, число внешних ключей и объем базы данных (Гб)

Результаты вычислений

Номер проекта	Эффективность CRS	Эффективность VRS	Эталонные проекты для данного проекта
1	0.367	0.450	11(0.250), 8 (0.750)
2	0.753	1.000	
3	0.667	1.000	
4	0.667	0.944	3 (0.167), 13 (0.111), 11 (0.722)
5	0.622	1.000	8
6	0.575	0.682	13 (0.016), 3 (0.221), 11 (0.496), 8 (0.267)
7	0.592	0.889	2 (0.500), 13 (0.167), 11 (0.333)
8	1.000	1.000	
9	0.295	0.400	8 (1.000)
10	0.413	0.530	13 (0.159), 11 (0.210), 3 (0.428), 8 (0.203)
11	1.000	1.000	
12	0.570	0.573	13 (0.067), 8 (0.200), 11 (0.733)
13	1.000	1.000	
14	0.438	0.438	11 (0.750), 8 (0.250)
15	0.505	0.625	8 (0.500), 11 (0.500)

Рекомендации для неэффективных объектов (проектов)

Проект номер 4. Уровень его эффективности равен 0.944

Показатель	Исходные значения	Рекомендуемые значения
Число человеко-часов высокой квалификации	9.000	3.611
Число человеко-часов средней квалификации	3.000	2.833
Число таблиц	7.000	8.000
Число внешних ключей	4.000	4.000
Объем базы данных (Гб)	4.000	4.000

Модель с ориентацией на вход, т. е. цель – получить рекомендации по *снижению* значений *входных* показателей. Но в ряде случаев могут выдаваться и рекомендации по *увеличению* значений *выходных* показателей. Это имеет место для показателя «Число таблиц»

Что делать с полученными результатами ?

- Гипотетический проект, который находится на границе эффективности, и будет являться целью для неэффективного проекта
- Исходят из того, что если какие-то объекты (в нашем случае – проекты) могут функционировать с высокой эффективностью, значит, и другие также *должны быть* в состоянии это делать
- Если они этого не делают, тогда нужно разбираться, в причинах: низкая квалификация специалистов, включенных в этот проект, низкая трудовая дисциплина, особенности заказчика конкретного проекта и т. д.

Пример – проектирование БД

Объекты исследования – проекты по разработке новых баз данных

Входные показатели:

- число человеко-часов труда специалиста высокой квалификации
- число человеко-часов труда специалиста средней квалификации

Выходные показатели:

- число таблиц в базе данных
- число внешних ключей (оно отражает сложность связей в БД)
- число атрибутов в таблицах

Вопрос тот же: насколько эффективно поработали наши проектировщики БД в каждом из проектов?

Обсуждение примера

- Повышение эффективности может выражаться в том, что участники проектов, не увеличивая свою численность, спроектируют более сложные базы данных (или более крупные фрагменты какой-то базы данных): содержащие больше таблиц и внешних ключей, рассчитанных на большие объемы хранимых данных и т. п.
- Следует выбирать модель с ориентацией на выход. Тогда мы получим для неэффективных проектов рекомендации по увеличению значений выходных показателей, т. е. числа таблиц и др.

Пример – оценка производительности работы специалистов

Можно в качестве членов выборки использовать кандидатов на вакантные должности и специалистов, уже работающих в компании

Входные показатели:

- опыт работы (в годах)

Выходные показатели:

- общий объем исходного кода, написанного программистом (число строк)
- число успешно завершенных проектов
- число языков программирования, СУБД или каких-то технологий, которыми владеет программист (как учесть уровень знаний?)

Исходные данные

Номер специалиста	Опыт работы (в годах)	Общий объем исходного кода (число строк)	Число успешно завершенных проектов	Число языков программирования, СУБД и технологий
1	18	185000	19	6
2	5	12000	3	3
3	10	57000	12	7
4	5	23000	5	3
5	8	45000	7	3
6	12	128000	16	8
7	7	37000	3	10
8	2	5000	1	3
9	32	250000	23	8
10	16	63000	15	2
11	10	71000	11	6
12	14	89000	18	5

Желтым цветом закрашены строки, соответствующие кандидатам на должность

Результаты вычислений

Номер специалиста	Эффективность CRS	Эффективность VRS	Эталонные специалисты для данного специалиста
1	0.964	1.000	
2	0.600	0.606	7 (0.100), 6 (0.250), 8 (0.650)
3	0.950	0.954	7 (0.076), 6 (0.762), 8 (0.162)
4	0.800	0.909	6 (0.300), 8 (0.700)
5	0.656	0.700	6 (0.600), 8 (0.400)
6	1.000	1.000	
7	1.000	1.000	
8	1.000	1.000	
9	0.732	1.000	
10	0.703	0.808	9 (0.111), 12 (0.889)
11	0.850	0.851	7 (0.012), 6 (0.794), 8 (0.194)
12	0.964	1.000	

Желтым цветом закрашены строки, соответствующие кандидатам на должность

Что делать с кандидатом?

Специалист номер 2. Уровень его эффективности равен 0.606

Показатель	Исходные значения	Рекомендуемые значения
Опыт работы (в годах)	5	5
Общий объем исходного кода (число строк)	12000	38950
Число успешно завершенных проектов	3	4.95
Число языков программирования, СУБД и технологий	3	4.95

Пример – оценка квалификации специалистов

В качестве членов выборки используем кандидатов на вакантные должности и специалистов, уже работающих в компании

Входные показатели:

- обобщенный входной показатель (равный 1 для всех специалистов)

Выходные показатели (оцениваются в баллах):

- уровень знаний языка SQL
- уровень знаний внутреннего устройства СУБД PostgreSQL
- уровень знаний операционной системы Linux

Исходные данные

Номер специалиста	Условный показатель затрат ресурсов	Уровень знаний языка SQL	Уровень знаний внутреннего устройства СУБД PostgreSQL	Уровень знаний операционной системы Linux
1	1	7	6	6
2	1	5	8	3
3	1	6	3	7
4	1	3	4	9
5	1	8	5	3
6	1	9	4	8
7	1	3	5	8
8	1	6	4	3
9	1	8	7	8
10	1	7	7	2
11	1	4	6	6
12	1	9	3	5

Желтым цветом закрашены строки, соответствующие кандидатам на должность

Результаты вычислений

Номер специалиста	Эффективность CRS	Эталонные специалисты для данного специалиста
1	0.871	9 (0.963), 6 (0.037)
2	1.000	
3	0.842	6 (0.687), 4 (0.312)
4	1.000	
5	0.935	6 (0.552), 9 (0.448)
6	1.000	
7	0.935	9 (0.448), 4 (0.552)
8	0.710	6 (0.455), 9 (0.545)
9	1.000	
10	0.966	2 (0.250), 9 (0.750)
11	0.837	9 (0.833), 2 (0.167)
12	1.000	6 (1.000)

Желтым цветом закрашены строки, соответствующие кандидатам на должность

Что делать с кандидатом?

Специалист номер 1. Уровень его эффективности равен 0.871

Показатель	Исходные значения	Рекомендуемые значения
Условный показатель затрат ресурсов	1	1
Уровень знаний языка SQL	7.000	8.037
Уровень знаний внутреннего устройства СУБД PostgreSQL	6.000	6.889
Уровень знаний операционной системы Linux	6.000	8.000

Рекомендации по применению метода

- Число объектов $N \geq \max \{ K \times M, 3(K + M) \}$
где K и M – числа входных и выходных переменных
- Число переменных – как правило, не более 5–6
- Для сокращения числа переменных исключать те, которые являются функционально зависящими от других переменных
- Для увеличения числа объектов в исследуемой группе можно включать в нее объекты с показателями за различные временные периоды

Программное обеспечение

- PIM-DEA Soft (Performance Improvement Management Software) (<http://deazone.com/en/software>)

Это коммерческое ПО

- DEAOS (DEA Online Software) (<https://www.deaos.com>)

Это web-приложение

- DEAP (<http://www.uq.edu.au/economics/сера/deap.php>)

Одна из самых популярных и известных программ. Автор – австралийский профессор Т. Coelli. Эта программа является свободным ПО. Консольное приложение

- И другое ПО...

Метод DEA в России

- Первые в России – профессор В. Е. Кривоножко и его аспиранты и коллеги из Института системного анализа РАН. Их первые статьи по этому методу вышли еще в конце 90-х годов прошлого столетия

Анализ эффективности функционирования сложных систем [Текст] / В. Е. Кривоножко, А. И. Пропой, Р. В. Сеньков, И. В. Родченков, П. М. Анохин // Автоматизация проектирования. – 1999. – № 1. – С. 2–7.

- Города России, в которых «знают» о методе DEA
 - Москва
 - Санкт-Петербург (СПбГУ, Ю. В. Федотов)
 - Барнаул
 - Иваново
 - Красноярск
 - Нижний Новгород
 - Самара

Публикации в России

- Защищено более 10 диссертаций (физико-математические, технические и экономические науки)
- Статьи в журналах (в т. ч. «Экономика и математические методы»)
- Доклады на конференциях
- Учебник


Кривоножко, В. Е. Анализ деятельности сложных социально-экономических систем [Текст] / В. Е. Кривоножко, А. В. Лычев. – М. : Издательский отдел факультета ВМ и К МГУ ; МАКС Пресс, 2010. – 208 с.

Русскоязычный эквивалент названия метода

- В. Е. Кривоножко и его коллеги используют такой – «Анализ Среды Функционирования» (АСФ)

В оригинальном названии метода есть слово envelopment (обертывание). Граница эффективности как бы огибает, или обертывает, точки, соответствующие исследуемым объектам в многомерном пространстве

- «метод обволакивающей поверхности»
- «метод оболочки данных»
- «анализ свертки данных»
- «непараметрический метод анализа оболочки данных (АОД)»
- «анализ „упаковки“ (охвата) данных»



Веб-ресурсы

Самый авторитетный ресурс

<http://www.deazone.com>

Его поддерживает профессор Ali Emrouznejad


В российском сегменте Интернета аналогичного web-ресурса найти не удалось

Наш веб-ресурс

<http://www.morgunov.org/efficiency.html>

- краткое введение в метод DEA
- практический пример проведения небольшого исследования
- кандидатские диссертации авторов настоящего доклада
- доклады на конференциях и статьи, в которых рассматривается, развивается или используется метод DEA
- авторская компьютерная программа. Эта программа пока что реализует только две модели метода DEA, которые называются моделями CCR и BCC (в их названиях используются первые буквы фамилий их авторов)

<http://www.morgunov.org/cgi-bin/dea/dea.pl>



Спасибо за внимание